

深層学習を用いた台風強度推定に対する台風の特徴の影響

加瀬 紘 熙^{*1}・筆保 弘 徳^{*2}・北本 朝 展^{*3}
Danlan Chen^{*4}・吉田 龍 二^{*5}・竹見 哲 也^{*6}

1. はじめに

機械学習は、人間が行っている学習能力と同様の機能をコンピュータで実現しようとする技術・手法のことである。特にニューラルネットワークを多階層構造にして、より複雑な関係性を表現出来る様にした学習を Deep Learning (深層学習) と呼ぶ。近年、計算機技術の飛躍的な発展に伴い、深層学習の課題とされてきた学習時間と計算コストが改善され、これまで以上に深層学習を用いた研究が盛んになった。そして気象学分野でも、深層学習を用いた研究が行われるようになった (Liu *et al.* 2016 ; Maskey *et al.* 2016 ; Onishi and Sugiyama 2017 ; Ebert-Uphoff *et al.* 2017 ; Hong *et al.* 2017 ; Kim *et al.* 2017a, b ; Matsuoka *et al.* 2017 ; Gorricha and Costa 2013 ; O'Connor *et al.* 2017 ; Seo *et al.* 2017 ; Vandal and Ganguly 2017 ; Pradhan *et al.* 2018)。

一方、気象庁は、海上における台風の位置・強度推定を、主にドボラック法 (Dvorak 1984) を用いて行っている。ドボラック法とは、Dvorak が衛星雲画像から得られた台風の雲パターンと強度を統計的に関連付け、雲パターンにより強度を推定するために確立

した方法である。基本的な概念として、衛星画像の解析から得られた熱帯低気圧の強度を表す指数として T 数を定義している。この T 数を調整し、CI 数を決めることで、台風中心気圧などの強度を推定している (気象庁予報部 1990)。台風監視業務としての台風の強度推定は、地上観測点から十分に離れた海上に台風がある時は、予報官が衛星雲画像から目視で行うドボラック法に頼らざるを得ない (近年では衛星マイクロ波が利用可能であるほか、場合によっては航空機観測が加わることもある)。

そこで、深層学習を用いれば、過去の多量の衛星雲画像データとその時の強度推定結果を学習することで衛星雲画像からより客観的に台風強度の推定が行えると考えられる。Maskey *et al.* (2016) は、衛星雲画像から深層学習による台風の強度分類の推定を行い機械学習の有用性を示した。Matsuoka *et al.* (2017) は、数値シミュレーション結果ではあるが、衛星雲画像に対応する上向き長波放射量から熱帯低気圧の強度別のクラスを深層学習を用いて検出している。

しかし、これまでの深層学習による台風の研究は、機械学習のアルゴリズム開発や精度向上を目的としたものであり、気象学的な視点から台風の特徴と強度推定の精度を論じた研究は皆無である。そこで本研究は、深層学習を用いた台風強度推定モデルを独自に開発し、特徴別に台風を分類して検証をすることで、台風の特徴によって台風強度推定モデルの精度がどう変わるかを調べる。なお、本研究の目的が機械学習のアルゴリズム評価ではないため、学習モデルの比較は行わない。深層学習を用いて作成した強度推定モデルが、どのような特徴を持つ台風の時に精度良く強度推定ができるのか、逆に強度推定が難しいかを統計的に調べる。

^{*1} 横浜国立大学大学院。

^{*2} (連絡責任著者) 横浜国立大学大学院。
fude@ynu.ac.jp

^{*3} 国立情報学研究所。

^{*4} McGill University。

^{*5} CIRES, NOAA ESRL/理化学研究所計算科学研究センター。

^{*6} 京都大学防災研究所。

—2018年6月21日受領—

—2018年11月6日受理—

2. 手法

2.1 深層学習モデル

本研究は、深層学習を用いた台風強度推定モデルを作成した。気象学の数値シミュレーション研究で用いられる「モデル」とは少し意味が異なるが、機械学習の分野では広く用いられていることから、本研究でも学習で得られた処理系をモデルと呼ぶことにする。

深層学習のモデルは順伝播型と再帰型に大別することができる。これらを台風強度推定に適用する場合、順伝播型は個々の時刻の画像を独立して学習するが、再帰型は時系列データとして過去のデータも参照しながら学習することを意味する。気象庁が用いているドボラック法は、推定時刻のみの衛星雲画像から台風強度を推定しているわけではなく、推定時刻の衛星画像とその数時間前までの時間変化を考慮している（気象庁予報部 1990）。そこで本研究では、ドボラック法になって再帰型をベースにした台風強度推定モデルを作成した。

本研究で開発した再帰型のモデルは、1時間ごとの衛星雲画像を用いて、時間的に連続した12枚（12時間分）の衛星雲画像を1セットとして学習するモデルとする。例えば、01UTC~12UTCを学習する場合、この期間の1時間ごとの衛星雲画像と気象庁ベストトラック（以後BTと記す）で得られた中心気圧を与えて学習させる。2セット目は02UTC~13UTCであり、これを台風発生時刻から台風消滅時刻まで繰り返す。そして、作成された強度推定モデルを用いて強度推定を行うときは、01UTC~11UTCの画像と中心気圧を読み込み、12UTCの画像から中心気圧を推定する。BTは6時間間隔（日本接近時は1時間間隔の場合もある。）であり、その間の気圧データは1時間間隔で学習をさせるために作成しなければならない。線形補間をすると、予測する時間のデータが学習情報に入ってしまうため適さない。本研究では、BTにある直近の気圧データを次のBTデータがある時間まで続けていると仮定して、1時間ごとの気圧データを作成している。ちなみに、BTを線形補間することで1時間ごとの気圧データを作成し、それを用いて解析も行ったが、本稿で示す結果と同様の結果を得ている。

本研究の深層学習では、あらかじめ必要なプログラムを組み合わせて作成されたソフトウェアの一群であるオープンソースニューラルネットワークライブラリ（フレームワーク）にKeras (<https://github.com/keras-team/keras/graphs/contributors>, 2018.11.6

閲覧)を使用し、スカラーやベクトルなどのテンソル計算を操作するためのテンソル操作ライブラリ（データ処理）にはTensorflow (<https://www.tensorflow.org>, 2018.11.6閲覧)を使用した。

本研究で構築するネットワークの構造は、以下の通りである。まず224×224のサイズに縮小した画像を畳み込みニューラルネットワーク（VGG-16）に入力し、画像特徴量を4096次元ベクトルに変換する。この方法で12時間分1セットの画像から時系列ベクトルを計算した結果を、300ニューロンのLong Short-Term Memory（LSTM）に入力し、その出力として中心気圧を予測する。LSTMは、長期的な時間方向の依存関係を学習することのできるニューラルネットワークの一種である。本研究では、学習データセット全てを1000epoch（1つの学習データを何回繰り返して学習させるかを示す数値の単位）学習させている。

2.2 学習・検証データ

本研究で対象とする台風は、BTに基づく1987年~2016年に発生した台風を対象とした。使用するデータは、北本（2000）が収集しアーカイブした静止気象衛星の赤外画像を元に作成された台風画像と、BTの中心気圧である。台風画像は、領域2600 km四方を用い、平均解像度は約5.1 kmである。地球の曲面については、ランベルト正積方位図法を用いることにより補正している。

全データを学習データと検証データに分割する際には、学習データと検証データの分離を確実なものとするため、画像ごとではなく台風ごとに分割を行った。この場合、個々の台風事例に含まれる約60~400のデータは、一体的に学習データまたは検証データに属することになる。また、衛星雲画像には、気象衛星の保守に伴う休止や太陽回避などによるノイズが混入する場合にデータの欠損が生じる。台風強度推定モデルの学習時に、1つの台風の発生から消滅までの間に1時間でもデータが欠損している場合、学習に差が生じる。本研究の目的である精度比較を公平に行えなくなるため、データが全て揃っている台風事例のみを学習・検証対象とした。学習データは1987年から2011年の170事例（32294データ）の台風、検証データは2012年から2016年の106事例（21501データ）の台風とした。全データの約60%が学習データ、約40%が検証データとなる。

台風特徴別の検証は、台風の特徴別で分けたグループごとに、強度推定モデルによる強度推定の精度検証

を行う。本研究での精度が高いという判定は、推定した台風中心気圧がBTに近いことを意味する。台風の特徴は、台風発生の季節、台風のライフタイムで最も強度が大きくなる時間（成熟期）での強度別、急速発達（Rapid intensification；RI）を経験・未経験の台風、台風発生時と成熟期のサイズ、台風の経路別、台風発生環境場パターン別である。台風発生時とは、気象庁が発表した台風発生時であり、トロピカルストーム（TS、低気圧域内の10分間平均最大風速がおよそ 17 m s^{-1} 以上）の強度に達した時間を指す。

本研究は、比較する両グループに有意な差があるのかを調べることを目的に、統計的検定を行っている。検定にあたってはT検定を用いて、95%有意の範囲で判定している。

3. 結果

3.1 学習の検証

本研究で開発した強度推定モデルが適切に学習できているかを判断するために、学習経過を検証した。学習経過の検証手法として、損失関数が学習回数とともにどのように推移するのかを確認する手法がよく用いられている。損失関数の場合、学習回数が進むにつれて減少していれば、その学習は正しく進んでいると判断できる。本研究の学習では、損失関数が減少していること（はじめ0.3程度であった損失関数の値は、開始直後から200epochの間に約0.2減少し、その後は0.1付近の値に落ち着く）を確認し、過学習などが起きずに学習が順調に進んでいた（図省略）。

BTの中心気圧と強度推定モデルが推定した中心気圧の全検証データセット（21501データ）に対するRMSEは9.87 hPaであった。それぞれの台風事例別（106事例）にRMSEをとると、11.86 hPaであった。


第1図は、検証に用いたBT中心気圧の全データと、強度推定モデルによる中心気圧推定値の発生頻度のヒストグラムである。

BTの頻度分布の特徴は、1010 hPa台と1000 hPa台で同程度で頻度が高く、990 hPa台以下では気圧が低くなるにつれて頻度は低下している。一方、強度推定モデルの推定値は、1000 hPa台で頻度が最も高くなり、1010 hPa台は980 hPa台の頻度と同程度まで低くなっている。1010 hPa台の頻度は、BTに対して推定値は約50%も減少している。一方、980-1000 hPa台でBTより推定値が10%程度増加している。つまり、BTで中心気圧の高い台風については、強度を過大評価（気圧を低く推定）する傾向がみられる。一方、910 hPa台以下の強度が強い台風は、データ数が少ないが、BTの435回に対して強度推定モデルの推定値は38回となっており約90%減少している。強度推定モデルは、中心気圧が低い（台風強度が強い）台風には過小評価（気圧を高く推定）する傾向がみられる。


第2図は、緯度経度 5° 四方の海域や陸域別で分けつけた、RMSEを示している。台風が最も発達しやすいフィリピン東部の海域でRMSEは大きくなっている。特に、強度推定モデルはBTの中心気圧よりも気圧を高く推定する過小評価傾向であった（図省略）。

3.2 台風事例別の検証


本研究では、台風事例ごとに強度推定モデルの検証を行っている。第3図は、台風事例ごとのBTと強度推定モデルにより推定された中心気圧の時系列であ



第1図 検証で扱った台風事例の気象庁ベストトラック（黒棒）と台風強度推定モデルによる中心気圧（白棒）のヒストグラム。



第2図 台風強度推定モデルによる5°四方の領域ごとのRMSE。黒が8 hPa以上、灰色が4 hPa以上の領域を示す。



第3図 (a) 2013年台風6号 (T1306), (b) 2014年台風2号 (T1402), (c) 2013年台風24号 (T1324), (d) 2013年台風23号 (T1323) の気象庁ベストトラックと台風強度推定モデルで推定された気圧時系列。実線はベストトラックの中心気圧, 点線は推定した中心気圧。

る。成熟期の中心気圧で比べてよく発達した台風とあまり発達しなかった台風のうち、さらにBTと強度推定モデル推定値の中心気圧の事例別RMSEが大き

かった台風と小さかった台風の4事例を示している。あまり発達しなかった台風では、2013年台風6号(以後T1306と記す)のように精度高く推定されている事例もあれば(RMSE4.87 hPa), T1402のように推定できていない(19.44 hPa)事例もある。よく発達した台風でも、T1324のように精度高く推定されている事例もあれば(6.83 hPa), T1323のように推定できていない(25.57 hPa)事例もある。

今回の検証期間で、事例別でみたRMSEの値が最も大きかった台風事例はT1601であり、30.83 hPaであった。一方、最も精度高く推定していた台風事例はT1305で、2.61 hPaであった。以上のように、台風

事例でみた場合、推定精度が高い事例もあれば、推定精度が低い事例もある。台風事例ごとの精度は、その台風の特徴に関係していると推察される。

本研究は検証対象の106事例の台風を特徴別に分けて、強度推定の精度を調べた。第4図の1-5月と6-8月と9-12月は、発生月別台風を示しており、発生月をそれぞれの月で発生した台風で分類している。


6-8月(41事例で8214データ)に発生したものは(RMSE8.61 hPa), 他(1-5月は14事例で2826データ, 9-12月は51事例で9888データ)よりもRMSEが小さい。つまり、夏季に発生する台風は、本研究で作成した台風強度推定モデルによる推定精度は高い傾向が見られた。6-8月とその他のグループで検定した結果、95%範囲で有意な差が確認された。

第4図のカテゴリ-4から1とTSランクは、成熟期の最大強度の分類を示している。強度には、Saffir-Simpsonスケール(Simpson 1974)を用いて分類しており、カテゴリ-4は低

気圧域内の10分間平均最大風速がおよそ59~69 ms^{-1} , カテゴリー3はおよそ50~58 ms^{-1} , カテゴリー2はおよそ43~49 ms^{-1} , カテゴリー1はおよそ33~42 ms^{-1} である. 検証した台風のうち, カテゴリー4の台風は7事例で1785データ, カテゴリー3は19事例で5427データ, カテゴリー2は15事例で3705データ, カテゴリー1は15事例で2958データ, TSは47事例で7053データであった. カテゴリー4からTSまで強度が小さくなるにつれて, RMSEが小さくなるということがわかった. つまり, 最大強度の強い(弱い)台風ほど推定精度は低い(高い).

RI経験の有無で比較した結果が, 第4図のRI経験とRI未経験である. 過去の研究(Fudeyasu *et al.* 2018)にならぬ, RI経験台風は24時間で30ノット(1ノット=0.5144 ms^{-1})以上の発達をした台風と定義して分類したところ, RI経験台風は35事例で8547データ, 未経験は71事例で12381データであった. そして, RI経験台風のRMSE(11.70 hPa)がRI経験の無い台風(8.48 hPa)よりも大きくなりやすいことが分かった. 2つのグループで検定した結果, 95%範囲で有意な差が確認された.

台風のサイズで分類するために, 台風の横方向のサイズとして風速30ノットの半径を指標として, 台風発生時と成熟期の30ノット長軸半径で, 150海里(1海里=1.852 km)より大きい小さいかで分類した. その結果, 台風発生時のサイズの違う台風のRMSEは, 有意な差が見られなかった(図略). しかし成熟期には, サイズが大きい台風(73事例で15882データ)の方では, 小さい台風(33事例で5046データ)と比べてRMSEが有意な差を持って大きくなった(第4図のサイズ大とサイズ小). つまり, 推定精度は, 台風発生時のサイズでの差はないが, 成熟期のサイズには



第4図 台風強度推定強度推定モデルにおける台風の特徴別で分けた絶対誤差の箱ひげ図(ただし, 四分位範囲のみ). 台風発生季節で1-5月, 6-8月, 9-12月, 成熟期における台風強度でスケールによるカテゴリー4, カテゴリー3, カテゴリー2, カテゴリー1, TSランク, 急速発達の経験と未経験, 成熟期の台風サイズでサイズが150海里よりも大きい台風と小さい台風, 台風の上陸国別で日本上陸, 中国上陸, ベトナム上陸, 台風発生環境場パターン別でSL, CR, GY, EW, PTC.

有意な差があり, 大きい台風ほど推定精度が低くなる傾向にある.

台風の経路別で分類するために, その台風がどの国に上陸したかを指標にした. 過去の研究(Fudeyasu *et al.* 2014)の定義を用いて, 日本, 中国, ベトナムの上陸台風に分類した. 日本上陸の台風は16事例で4083データ, 中国は29事例で5313データ, ベトナムは18事例で2580データであった. その結果(第4図の日本, 中国, ベトナム上陸), ベトナムに上陸する台風のRMSEは小さく(6.83 hPa), 一方で日本に上陸する台風(11.00 hPa)は約2倍も大きくなることがわかった. つまり, ベトナムに上陸する台風は推定精度が高く, 日本に上陸する台風の中心気圧は推定精度が低い傾向にあった.

最後に, 台風発生環境場パターンで台風を分類した. Ritchie and Holland (1999)によると, 台風の発生環境場は対流圏下層の大規模な風パターンより, 以下の5パターンに分けられるとしている. シアラインパターン(SL), 東西風合流域パターン(CR), モンスーンジャイアパターン(GY), 偏東風波動パターン(EW), 既存の台風の南東側で発生するパ

ターン (PTC) である。Yoshida and Ishikawa (2013) の発生環境場分類手法により、本研究で検証対象とした台風を客観的に発生環境場で分類したところ、SLは38事例で8085データ、CRは24事例で4044データ、GYは4事例で660データ、EWは19事例で4107データ、PTCは7事例で1737データとなった。それぞれの絶対誤差の中央値をみると(第4図のSL, CR, GY, EW, PTC), SLとGYで発生した台風は他の環境場と比べて大きくなることがわかった。一方、CRとEWとPTCで発生した台風は他の種類と比べて小さくなることがわかった。

4. 考察とまとめ

本研究は、台風を中心とした衛星雲画像とBTの中心気圧を学習データとして深層学習を用いた台風強度推定モデルを作成し、台風の特徴と台風強度推定の精度を調べた。作成した台風強度推定モデルは、さかのぼる時間を11時間とする再帰型をベースとした。精度検証をした結果は以下である。

- (結果1) 中心気圧が高く強度が弱い時と、中心気圧が低く強度が強い時で、それぞれ過大評価と過小評価する傾向がある。
 - (結果2) フィリピン東部の海域で推定精度は低くなる。
 - (結果3) 台風事例別でみると、検証対象の台風の中ではRMSEは最大30.83 hPa (T1601), 最小2.61 hPa (T1305) である。
 - (結果4) 春や秋冬に発生する台風と比べて、夏に発生する台風の推定精度は高い傾向にある。
 - (結果5) 成熟期での最大台風強度別で比べると、弱い台風の方が推定精度は高い傾向にある。
 - (結果6) RI 経験のある台風は、未経験の台風に比べて推定精度は低い傾向にある。
 - (結果7) 台風発生時のサイズ別の推定精度で差はないが、成熟期ではサイズが大きい台風が小さい台風よりも推定精度は低い傾向にある。
 - (結果8) ベトナムに上陸する台風の推定精度は高く、日本に上陸する台風の推定精度は低い傾向にある。
 - (結果9) SLとGYのパターンで発生した台風の推定精度は低く、CRとEWとPTCパターンで発生した台風は推定精度が高い傾向にある。
- 深層学習を用いた台風強度推定モデルは、データ

セット(過去の経験)を基に作成されるため、学習データに含まれている特徴別の台風事例数に依存する(Yan *et al.* 2015)。つまり、学習データの中で推定対象の台風と類似した台風の事例数が少ない場合は、精度が低くなると考えられる。(結果6)では、RIを経験した台風はRI未経験の台風よりも推定精度が低いが、RIを経験した台風はRI未経験の台風よりも事例数が半分程度となっているという偏りが原因だと考えられる。

一方、(結果5)強度が強い台風ほどRMSEが大きくなる点は、学習に用いるBTの精度が原因となる可能性がある。木場ほか(1990)によると、弱い強度の時と比べて、強い強度の時では不確実性が大きく、30 hPa以上の誤差がある場合も指摘している。つまり(結果5)のように、台風強度が強いほど誤差が大きいBTと比較することにより、結果として推定精度が低くなることも考えられる。それに伴い、(結果2)のように台風強度が強くなるフィリピン東部の海域では、精度が低くなることも考察できる。さらに、日本に上陸した台風は、中国やベトナムに上陸した台風よりも成熟期の強度が強い台風が多い(結果8)ことも考察できる。BTの不確実性については、もともと海上の台風の強度は比較・検証をするデータが少ないことが原因であり、そのためIto *et al.* (2018)の航空機による台風強度の直接観測は、本研究のような深層学習にとっても期待が高い。

以上のように台風強度推定の推定精度は、学習データの偏りと、強い台風におけるBTの不確実性で考察したが、(結果1)(結果4)(結果7)(結果9)のようにそれだけでは説明がつかない結果もある。以上の結果の原因解明は今後の研究の課題とするが、画像認識の観点から学習を反復するうちに得られた特徴抽出部分を解析するなど、どの領域の雲域(または非雲域)でその気圧を予測したか、予測に対する物理的な解明まで進めたい。

謝辞

本研究は、京都大学防災研究所の山崎聖太様、気象予報士の清原康友様、海洋研究開発機構の松岡大祐様、横浜国立大学の金崎拓郎様、琉球大学の伊藤耕介博士ならびに琉球大学の学生の皆さま、気象研究所の小山 亮博士からは大変有益なご助言を頂きました。感謝申し上げます。京都大学防災研究所共同研究29K-04, 29G-05, 日本学術振興会科学研究費助17

H02956の支援も受けて実施されました。

参考文献

- Dvorak, V. F., 1984: Tropical cyclone intensity analysis using satellite data. NOAA Tech. Rep. NESDIS 11, 47pp.
- Ebert-Uphoff, I., D. R. Thompson, I. Demir, Y. R. Gel, M. C. Hill, A. Karpatne, M. Guereque, V. Kumar, E. Cabral-Cano and P. Smyth, 2017: A vision for the development of benchmarks to bridge geoscience and data science. Proc. 7th Int. Workshop Climate Inf.: CI2017 (V. Lyubchich *et al.*, ed.), 49-52.
- Fudeyasu, H., S. Hirose, H. Yoshioka, R. Kumazawa and S. Yamasaki, 2014: A global view of the landfall characteristics of tropical cyclones. Trop. Cyclone Res. Rev., 3, 178-192.
- Fudeyasu, H., K. Ito and Y. Miyamoto, 2018: Characteristics of tropical cyclone rapid intensification over the Western North Pacific. J. Climate, 31, 8917-8930.
- Gorricha, J. and A. C. Costa, 2013: A framework for exploratory analysis of extreme weather events using geostatistical procedures and 3D self-organizing maps. Int. J. Adv. Intel. Syst., 6, 16-26.
- Hong, S., S. Kim, M. Joh and S. Song, 2017: GLOBENET: Convolutional neural networks for typhoon eye tracking from remote sensing imagery. Proc. 7th Int. Workshop Climate Inf.: CI2017 (V. Lyubchich *et al.*, ed.), 69-72.
- Ito, K., H. Yamada, M. Yamaguchi, T. Nakazawa, N. Nagahama, K. Shimizu, T. Ohigashi, T. Shinoda and K. Tsuboki, 2017: Analysis and forecast using dropsonde data from the inner-core region of tropical cyclone Lan (2017) obtained during the first aircraft missions of T-PARC II. SOLA, 14, 105-110.
- Kim, S. K., S. Ames, J. Lee, C. Zhang, A. C. Wilson and D. Williams, 2017a: Massive scale deep learning for detecting extreme climate events. Proc. 7th Int. Workshop Climate Inf.: CI2017 (V. Lyubchich *et al.*, ed.), 17-20.
- Kim, S., S. Hong, M. Joh and S.-K. Song, 2017b: DEEP-RAIN: ConvLSTM network for precipitation prediction using multichannel radar data. Proc. 7th Int. Workshop Climate Inf.: CI2017 (V. Lyubchich *et al.*, ed.), 89-92.
- 気象庁予報部, 1990: 予報作業指針: 台風予報, 気象庁, 150pp.
- 北本朝展, 2000: 台風画像コレクションの構築および台風解析への応用. NII J., 1, 7-22.
- 木場博之, 萩原武士, 小佐野慎悟, 明石修平, 1990: 台風のCI数と中心気圧及び最大風速の関係. 気象庁研究時報, 42, 59-67.
- Liu, Y., E. Racah, Prabhat, J. Correa, A. Khosrowshahi, D. Lavers, K. Kunkel, M. Wehner and W. Collins, 2016: Application of deep convolutional neural networks for detecting extreme weather in climate datasets. Proc. 3rd Int. Conf. Adv. Big Data Anal., 81-88.
- Maskey, M., R. Ramachandran, R. Pradhan and J. J. Miller, 2016: Deep learning-powered insight from dark resources. <https://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/20160014829.pdf> (2018.11.6閲覧).
- Matsuoka, D., M. Nakano, D. Sugiyama and S. Uchida, 2017: Detecting precursors of tropical cyclone using deep neural networks. Proc. 7th Int. Workshop Climate Inf.: CI2017 (V. Lyubchich *et al.*, ed.), 73-76.
- O'Connor, A., R. Bell, B. Kirtman and J. Gorman, 2017: Long-range forecasting using compass machine learning. Proc. 7th Int. Workshop Climate Inf.: CI2017 (V. Lyubchich *et al.*, ed.), 57-60.
- Onishi, R. and D. Sugiyama, 2017: Deep convolutional neural network for cloud coverage estimation from snapshot camera images. SOLA, 13, 235-239.
- Pradhan, R., R. S. Aygun, M. Maskey, R. Ramachandran and D. J. Cecil, 2018: Tropical cyclone intensity estimation using a deep convolutional neural network. IEEE Trans. Image Process., 27, 692-702.
- Ritchie, E. A. and G. J. Holland, 1999: Large-scale patterns associated with tropical cyclogenesis in the western Pacific. Mon. Wea. Rev., 127, 2027-2043.
- Seo, S., A. Mohegh and G. B. Y. Liu, 2017: Graph convolutional autoencoder with recurrent neural networks for spatiotemporal forecasting. Proc. 7th Int. Workshop Climate Inf.: CI2017 (V. Lyubchich *et al.*, ed.), 85-88.
- Simpson, R. H., 1974: The hurricane disaster potential scale, Weatherwise, 27, 169-186.
- Vandal, T. and A. R. Ganguly, 2017: Uncertainty quantification for statistical downscaling using Bayesian deep learning. Proc. 7th Int. Workshop Climate Inf.: CI2017 (V. Lyubchich *et al.*, ed.), 29-32.
- Yan, Y., M. Chen, M.-L. Shyu and S.-C. Chen, 2015: Deep learning for imbalanced multimedia data classification. Proc. 2015 IEEE Int. Symp. Multimed., 483-488.
- Yoshida, R. and H. Ishikawa, 2013: Environmental factors contributing to tropical cyclone genesis over the western north Pacific. Mon. Wea. Rev., 141, 451-467.

Impacts of Typhoon Characteristics on Typhoon Intensity Estimation Using Deep Learning

Koki KASE^{*1} • Hironori FUDEYASU^{*2} • Asanobu KITAMOTO^{*3}
Danlan CHEN^{*4} • Ryuji YOSHIDA^{*5} • Tetsuya TAKEMI^{*6}

^{*1} Graduate School of Education, Yokohama National University.

^{*2} (Corresponding author) Graduate School of Education, Yokohama National University. 79-2 Tokiwadai, Hodogaya-ku, Yokohama, 240-8501, Japan.

^{*3} National Institute of Informatics.

^{*4} McGill University.

^{*5} CIRES, NOAA ESRL / RIKEN Center for Computational Science.

^{*6} Disaster Prevention Research Institute, Kyoto University.

(Received 21 June 2018; Accepted 6 November 2018)
